

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Karlo – Josip Andrić

Zagreb, veljača 2016.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentor:

prof. dr. sc. Neven Duić, dipl. ing.

Student:

Karlo-Josip Andrić

Zagreb, veljača 2016.

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Zahvaljujem prof.dr.sc. Nevenu Duiću i doc.dr.sc. Luki Perkoviću, na stručnoj i nesebičnoj pomoći prilikom izrade ovog rada.

Karlo – Josip Andrić



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za završne ispite studija strojarstva za smjerove:
procesno-energetski, konstrukcijski, brodstrojarski i inženjersko modeliranje i računalne simulacije

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

ZAVRŠNI ZADATAK

Student: **Karlo Josip Andrić**

Mat. br.: 0035185931

Naslov rada na
hrvatskom jeziku:

**Modeliranje energetskih sustava koji sadrže jedinice za proizvodnju
energije iz visokih vjetrova**

Naslov rada na
engleskom jeziku:

**Modelling of energy systems containing the units for power production
from high altitude winds**

Opis zadatka:

Sustav za dobivanje energije iz visinskih vjetrova, baziran na Magnusovom efektu izrazito je diskontinuiran proces zbog postojanja dviju odvojenih faza proizvodnje i potrošnje energije. S obzirom na zahtjeve za čim stabilnijom predajom električne energije u mrežu, diskontinuitet u proizvodnji je moguće smanjiti na dva načina: (1) korištenjem većeg broja pojedinačnih vjetroelektrana u vjetroparku ili (2) korištenjem spremnika energije.

U sklopu ovog zadatka je potrebno provesti računalne simulacije u aplikaciji EnergyPLAN za primjer jednog izoliranog energetskog sustava koji se sastoji od potražnje energije, jedinica za proizvodnju električne energije iz visokih vjetrova koji u sebi sadrže i sustav za pohranu energije radi kompenzacije diskontinuiteta u proizvodnji, dizelskih i fotonaponskih jedinica. Simulacijama je potrebno procijeniti isplativost sustava za proizvodnju električne energije iz visokih vjetrova. Treba procijeniti koliko se povećava isplativost projekta ukoliko se omogući spoj s glavnom elektroenergetskom mrežom.

Sva literatura, modeli te ulazni podaci za analizu slučaja će biti dostupni od strane mentora i neposrednog voditelja. To su prije svega ulazni podaci za model EnergyPLAN (tehnički i ekonomski) te podaci za modeliranje sustava proizvodnje električne energije iz visokih vjetrova. U radu navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:

25. studenog 2015.

Rok predaje rada:

1. rok: 25. veljače 2016

2. rok (izvanredni): 20. lipnja 2016.

3. rok: 17. rujna 2015.

Predviđeni datumi obrane:

1. rok: 29.2., 02. i 03.03. 2016.

2. rok (izvanredni): 30. 06. 2016.

3. rok: 19., 20. i 21. 09. 2016.

Zadatak zadao:

Prof. dr. sc. Neven Duić

Predsjednik Povjerenstva:

Prof. dr. sc. Igor Balen

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS GRAFIKONA	IV
POPIS TABLICA.....	VI
POPIS KRATICA	VII
SAŽETAK.....	VIII
SUMMARY	IX
1. UVOD	1
1.1. Povijest	1
1.2. Općenito o tehnologiji	2
1.2.1. Načini prihvata i pretvorbe energije visinskih vjetrova	3
1.2.2. Prednosti i nedostaci.....	3
1.3. Koncepti, projekti i prototipovi	4
1.3.1. HAWE.....	4
1.3.2. KiteGen	6
1.3.3. MARS.....	7
1.3.4. Laddermill	7
1.3.5. BAT	7
1.3.6. Makani Wind Power Airbourne Wind Turbine.....	8
1.3.7. PowerPlane.....	8
2. DEFINICIJA PROBLEMA.....	9
2.1. HAWE jedinica.....	10
2.2. Potrošnja električne energije (Demand)	10
2.3. Spremnik električne energije (Storage)	11

2.4.	Fotonaponske jedinice (PV)	11
2.5.	Diesel jedinica i gorivo (Fuel)	12
2.6.	Uvoz/Izvoz električne energije (Import/Export)	12
3.	METODOLOGIJA	13
3.1.	Dijagram toka	13
3.2.	EnergyPLAN	14
3.3.	IRR.....	15
3.4.	LCOE.....	16
3.5.	Analiza osjetljivost	17
4.	ANALIZA REZULTATA.....	20
4.1.	Analiza ukupnih troškova zadanih scenarija	20
4.2.	Analiza unutarnje stope povrata	34
4.3.	Analiza niveliranog troška električne energije	37
4.4.	Analiza osjetljivosti	42
5.	ZAKLJUČAK	45
	LITERATURA I REFERENCE.....	46

POPIS SLIKA

Slika 1 : Faza proizvodnje	5
Slika 2 : Faza vraćanja u prvobitni položaj	6
Slika 3 : Blok shema EE sustava	9
Slika 4 : Satna krivulja distribucije HAWE jedinice.....	10
Slika 5 : Satna krivulja potrošnje električne energije.....	11
Slika 6 : Satna krivulja distribucije PV jedinice	12
Slika 7 : Dijagram toka.....	13
Slika 8 : Shematski prikaz EnergyPLAN programa.....	14
Slika 9 : Unos snage PV jedinice	21
Slika 10 : Unos veličine električnog spremnika	21
Slika 11 : Uvoz dopuštenog uvoza i izvoza električne energije.....	22

POPIS GRAFIKONA

Grafikon 1 : Ukupni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 1. scenarija.....	24
Grafikon 2 : Ukupni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 2. scenarija.....	24
Grafikon 3 : Ukupni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 3. scenarija.....	25
Grafikon 4 : Ukupni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 4. scenarija.....	25
Grafikon 5 : Fiksni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 1. scenarija.....	26
Grafikon 6 : Fiksni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 2. scenarija.....	27
Grafikon 7 : Fiksni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 3. scenarija.....	27
Grafikon 8 : Fiksni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 4. scenarija.....	28
Grafikon 9 : Varijabilni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 1. scenarija.....	29
Grafikon 10 : Varijabilni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 2. scenarija.....	30
Grafikon 11 : Varijabilni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 3. scenarija.....	30
Grafikon 12 : Varijabilni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 4. scenarija.....	31
Grafikon 13 : Investicijski godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 1. scenarija.....	32
Grafikon 14 : Investicijski godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 2. scenarija.....	33
Grafikon 15 : Investicijski godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 3. scenarija.....	33

Grafikon 16 : Investicijski godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 4. scenarija.....	34
Grafikon 17 : Kretanje IRR-a po scenarijima	36
Grafikon 18 : Kretanje godišnjih prihoda od el. energije.....	36
Grafikon 19 : Usporedba LCOE (HAWE) i LCOE (PV).....	39
Grafikon 20 : Usporedba proizvedene godišnje električne energije od HAWE i PV jedinica	40
Grafikon 21 : Analiza udjela proizvodnje el. energije PV i HAWE jedinica u odnosu na ukupnu proizvodnju.....	41
Grafikon 22 : Usporedba kretanja IRR-a analizom osjetljivosti za sve scenarije	43
Grafikon 23 : Usporedba kretanja promjena IRR-a analizom osjetljivosti za sve scenarije	44

POPIS TABLICA

Tablica 1 : Optimalne točke minimalnih ukupnih troškova	23
Tablica 2 : Optimalne točke fiksnih troškova	26
Tablica 3 : Optimalne točke varijabilnih troškova	29
Tablica 4 : Optimalne točke investicijskih troškova	32
Tablica 5 : Analiza IRR-a za sve scenarije	35
Tablica 6 : Analiza LCOE-a.....	38
Tablica 7 : Analiza udjela godišnje proizvedene električne energije u ukupno proizvedenoj .	41
Tablica 8 : Popis IRR-a uslijed analize osjetljivosti za sve scenarija	42
Tablica 9 : Popis promjena IRR-a uslijed analize osjetljivosti za sve scenarije	43

POPIS KRATICA

HAWE	-	High Altitude Wind Energy
LCOE	-	Levelized Cost of Electricity
IRR	-	Internal Rate of Return
MARS	-	The Magen Air Rotor System
BAT	-	The Buoyant Airbourne Turbine
EES	-	Elektro – energetska sustava
PV	-	Photovoltaic
OIE	-	Obnovljivi izvori energije
NPV	-	Net Present Value
RES	-	Renewable Energy Sources
PES	-	Primary Energy Supply
E	-	Instalirani spremnik električne energije
Ppv	-	Instalirana snaga PV modula

SAŽETAK

U vremenima kada konvencionalne vjetroelektrane preuzimaju sve veću ulogu u proizvodnji električne energije u svijetu, pojavila se relativno nova tehnologija koja iskorištava visinske vjetrove. Ta tehnologija je još u razvoju, ali čeka ju svjetla budućnost zbog toga što ima mnogo prednosti i mjesta za napredak. U ovom radu prikazati će se postupak modeliranja jednog elektro-energetskog sustava koji sadrži jedinice za proizvodnju energije iz visinskih vjetrova. Simulacije će se raditi u EnergyPLAN programu. Analizirat će se isplativost takvog sustava te u kojoj mjeri na nju utječu različiti parametri. Nakon odabira četiri najbolja scenarija u pogledu ukupnih troškova, sustav će se provesti u proračun isplativosti putem IRR i LCOE funkcija. Zatim će se provesti analiza osjetljivosti gdje će se ispitivati kako se sustav ponaša ukoliko se mijenja jedna varijabla u proračunu. Provedene analize pokazale su kako je četvrti scenarij najisplativiji koji je imao 750MW fotonaponskih modula, 1000MW visinskih vjetroelektrana, 50GWh spremnika električne energije te 100MW dopuštenog uvoza i izvoza električne energije. Time se dokazalo da će uvoz i izvoz električne energije te pohrana električne energije imati veliku ulogu u bliskoj budućnosti u pogledu iskorištenja energije visinskih vjetrova i energije općenito te daljnji razvitak pohrane i distribucije električne energije.

Ključne riječi: Modeliranje, EnergyPLAN, Energija visinskih vjetrova, Fotonaponski modul, vjetroelektrane, Analiza osjetljivosti, LCOE, IRR, Spremnik električne energije, Uvoz i izvoz električne energije

SUMMARY

In the time when conventional wind power plants take over greater part in electrical energy production in the world, there is relatively new technology which exploits high altitude wind energy. The technology is still developing, but it has a bright future while it has many advantages and enough room for improvements. This paper will show the modelling process of a power system which contains units for power production from high altitude winds. Simulations will be conducted in EnergyPLAN model. The profitability of power system will be analyzed and in what measure will different parameters affect its profitability. After four cases are selected in terms of overall costs, system will be carried out through calculation with IRR and LCOE functions. Then the sensitivity analysis will be carried out where the system will be tested how it will react if one variable in calculation is changed. The analyses showed that the fourth case is the most profitable one. It had 750 MW of photovoltaic modules, 1000MW HAWT units, 50GWh electrical energy storage and 100MW of electricity import and export capacity. It proved that electrical energy import and export and electrical energy storage will have a major role in near future in terms of high altitude wind energy exploitation and energy in general as much as in further development of electrical energy storage and its import and export.

Key words: Modelling, EnergyPLAN, HAWT, Photovoltaic modules, Wind power plants, Sensitivity analysis, LCOE, IRR, Electrical energy storage, Electricity import and export

1. UVOD

Upotreba vjetra kao obnovljiv izvor energije više nije nova stvar. Mnoge zemlje kao Njemačka, Danska i Norveška prepoznale su vjetar kao vrlo koristan izvor u pretvaranju njegove kinetičke energije, putem mehaničke u električnu energiju koja je prijeko korisna svima. Pa stoga u zadnjih par godina postoje velika ulaganja u izgradnju, istraživanje i razvoj novih konvencionalnih vjetroturbina. Grade se veliki vjetroparkovi koji mogu opskrbljivati čitave gradove električnom energijom. No, takve konvencionalne turbine imaju uz svoje velike prednosti i svoja ograničenja. Nizinski vjetrovi su diskontinuirani po vremenu i snazi te su slabiji od visinskih. Osim toga, konvencionalne vjetroelektrane imaju svoj visinski limit zbog svoje konstrukcije te ne mogu izdržati nalete vjetra na većim visinama koji su na tim visinama puno intenzivniji. Također, investicijski troškovi su još uvijek dosta veliki.

Upravo zbog toga pojavila se težnja za pretvaranjem ideje u djelo na način da se napravi prototip koji bi iskorištavao energiju visinskih vjetrova koji su postojaniji i veći po magnitudi. Stoga imamo veću gustoću snage te veći energetske potencijal za dobivanje korisne električne energije nego konvencionalne turbine. Ovakvim načinom iskorištenja energije vjetra smanjuje se trošak građevinskih radova. Manji je zahtjev za površinom, a utrošak materijala je smanjen i do 90% [1][2]. Zbog toga je jeftinija jedinična cijena instalirane snage i manja jedinična proizvodna cijena isporučene električne energije u odnosu na konvencionalne vjetroturbine. Također, zanimljivo je napomenuti da dnevni potencijal energije visinskih vjetrova u svijetu iznosi oko 3600TW dok naša dnevna potreba za energijom je 15TW [3]. Ova tehnologija ima veliki potencijal za istraživanje i razvoj [4].

1.1. Povijest

Visinske vjetroelektrane su još davne 1833. zamišljene kao izvor energije vizijom Johna Eltzera tako da uhvati snagu vjetra visoko u zraku koristeći se tehnologijom kabla i povodca [5]. Jedan od pionira u nedavnoj povijesti u izgradnji modernih vjetroelektrana koje iskorištavaju energiju vjetra u višim slojevima atmosfere je bio Australijski inženjer

Bryan Roberts [5]. Njegovo ime je bitno za ovo područje znanosti jer je u suradnji sa nekoliko američkih investitora napravio prototip nazvan „Flying Electric Generator“ koji je izgledom podsjećao na helikopter s četiri propelera bez kabine te je na visini od četiri do pet kilometara u zraku iskorištavao energiju vjetra [5]. Ovaj projekt je svrstan među 50 najboljih izuma 2008. godine od strane magazina Time [5]. Koncept je bio zamišljen tako da pomoću krila koja stvaraju uzgon od vjetra može letjeti u zraku, a pomoću kabela usidrenog na tlu prototip bi se održavao na mjestu. Prema riječima dizajnera dio energije bi se trebao trošiti na uzgon, dok bi stalan i jak vjetar omogućavao konstantnu proizvodnju električne energije [5]. Budući da vjetrovi uglavnom pušu u horizontalnom smjeru, generator bi po tom konceptu trebao biti položen pod nekim kutom od horizontale. Postavljanje prototipa bi se izvodilo tako da se električna energija dovede turbini čime ona postaje motor podižući prototip do zadane visine. U posljednjih 5 godina razvilo se mnogo radova i članka na temu visinskih vjetroelektrana [6][7][4], ideja [8], koncepata [9] i prototipa od strane mnogobrojnih malih tvrtka i znanstvenika koje rade naporno da se glas o ovim vjetroelektranama čuje te da se one probiju u narednim godinama do razine gdje ćemo imati komercijalnu upotrebu takvih prototipa.

1.2. Općenito o tehnologiji

Vjetrovi na većim visinama postaju mirniji, stalniji te postižu velike brzine. Budući da se energija koja je sadržana u vjetru povećava sa kvadratom brzine, uz pretpostavku da svi ostali parametri konstanti, udvostručenjem brzine dobivamo osam puta veću snagu, a utrostručenjem 27 puta veću snagu [10]. Generatori dizajnirani za visinske vjetrove mogu se podešavati u visini i poziciji da povećaju povrat energije do maksimuma dok je takva praksa sa fiksnim generatorima na vrhovima konvencionalnih vjetroelektrana nemoguća [10]. Za svaki stupanj visine postoji određeni problem na koji istraživači i konstruktori moraju obratiti pažnju. Kako visina raste, kabel na koji je pričvršćen uređaj za prihvaćanje energije visinskih vjetrova postaje sve duži, temperatura zraka se mijenja, a rizik od atmosferskih promjena raste [10]. Promjenom visine rastu troškovi brige i održavanja, turbulencija raste, a i raste vjerojatnost da će sistem letjeti u više nego jednom smjeru. Stoga tehnologija prikupljanja energije iz visinskih vjetrova ima svoju donju i gornju granicu od koje i do koje se mogu nalaziti. Donja granica se nalazi iznad visine konvencionalnih vjetroelektrana, dok je gornja granica definirana tehničkim uvjetima

(duljina kabla, težina lebdeće jedinice) i gore navedenim problemima na većim visinama [11][2].

1.2.1. Načini prihvata i pretvorbe energije visinskih vjetrova

Postoje različiti mehanizmi za prihvata kinetičke energije vjetra počevši od mehaničkih i laganih zmajolikih uređaja, koji lete u osmicu, cilindričnih balona, aerostata, zmajeva s turbinama za regenerativno lebdjenje, pa do čvrstih lebdjelica sa turbinama ili krilcima od ugljičnih vlakana. ti mehanizmi uključuju hvatišta za više lokacija na infrastrukturi ili na običnim ruralnim terenima [10]. Konstrukcija, izgled i dizajn nisu bitni dokle god je mehanizam funkcionalan. Neki su bolji za upotrebu u vjetroparkovima, dok su drugi bolji za upotrebu za manja postrojenja ili kućanstva. Mnogo je načina za eksploataciju mehaničke energije nastale iz kinetičke energije vjetra. Jedan od njih je uporaba vlaka za transportne svrhe, drugi izravno pretvara mehaničku energiju u električnu na visini ili u postaji na tlu, dok treći ju treći pak konvertira u laserske zrake ili mikrovalove u svrhu emitiranja zraka na zrakoplov ili prijamnik na zemlji [10]. Generator koji se može nalaziti ili na samom mehanizmu ili na tlu može se koristiti za isporučivanje električne energije industriji ili kućanstvima ako imamo veće vjetroparkove. Manji vjetroparkovi mogu generatorima snabdijevati pumpe ili kompresore ili ostale manje uređaje koji zahtijevaju električnu energiju za rad.

1.2.2. Prednosti i nedostaci

Visinskim vjetroelektranama se može podešavati visina i pozicija kako bi se maksimizirala dobivena energija vjetra što je nepraktično kod konvencionalnih vjetroelektrana na zemlji. Sustavi visinskih vjetroelektrana ne emitiraju stakleničke plinove te nisu opasne po zdravlje ljudi i životinja. Neki upućuju na ometanje zračnog prostora te na povećani rizik od zrakoplovnih nesreća. No, gledajući kao primjer SAD, da se pokriju potrebe SAD-a za električnom energijom, visinske vjetroelektrane trebale bi koristiti samo jednu četiristotinu njegovog zračnog prostora [5]. Povećanjem visine, produljuju se vodiči, intenzitet vremenskih nepogoda sve je izraženiji, temperatura zraka i turbulencija se mijenja, dok se troškovi povećavaju. Također valja napomenuti da su neke od visinskih vjetroelektrana napravljene od metala što povećava opasnost od munja kao

što proučavaju radovi [12] i [13]. Jači naleti vjetra koji vladaju na većim visinama predstavljaju problem jer mogu istrgnuti sustav iz svog ležišta. Zbog toga bi se one morale pozicionirati van naseljenih mjesta. Također još uvijek su troškovi rada veliki i teško je dobiti dozvolu za izgradnju visinskih vjetroelektrana [14].

1.3. Koncepti, projekti i prototipovi

U svijetu trenutno nema komercijalne uporabe tehnologije na visinske vjetrove, ali zato postoje mnogobrojni koncepti, projekti i prototipovi [15] istih od koji su mnogi u fazi testiranja, izrade i dorade, a neki su neaktivni zbog nedovoljnih novčanih poticaja. Samo je jedan od svih tih projekata uspješno završio fazu prototipa (HAWE) . Spomenut ćemo najznačajnije među svima njima.


1.3.1. HAWE

HAWE je bio projekt tvrtke Omnidea, jedini je projekt koji je prošao fazu prototipa i dosad jedan je od vodećih projekata u području proizvodnje energije iz visinskih vjetrova [16].


HAWE sistem je u konačnici vrlo jednostavan. Sastoji se od zemaljskog postrojenja koje se nalazi na tlu, od lebdeće jedinice koja je valjkastog oblika te od kabela koji međusobno spaja lebdeću jedinicu i zemaljsko postrojenje. Zemaljsko postrojenje se uglavnom sastoji od koluta oko kojeg je namotan kabel, od generatora kojim se generira električna energija dok se kolut s kabelom odmotava te od motora koji služi za pokretanje koluta kada treba navući kabel. U slučaju da nije povezan na mrežu ovakav sistem mora još i imati sistem za pohranu električne energije, a to može biti baterija, zamašnjak ili ultrakondenzator.

Proces prikupljanja kinetičke energije visinskih vjetrova te njenog pretvaranja u mehaničku pa potom u električnu energiju teče u dvije faze koje se ponavljaju. Prva faza takozvana faza proizvodnje teče tako da se lebdeća jedinica pusti u rad tako da uz pomoć vjetra, uzgona i Magnussovog efekta [17] te se lagano diže u visine i odmotava kabel sa bubnja, koji se nalazi na zemaljskom postrojenju, i pokreće generator koji generira električnu energiju. Lebdeća jedinica je točno usmjerena da vjetru stvara takav otpor koji

će omogućiti njeno podizanje. Faza proizvodnje prikazana je na Slika 1 [2]. Druga faza takozvana faza vraćanja u prvobitni položaj kreće kada lebdeća jedinica postigne svoju maksimalnu visinu. Okretanjem lebdeće jedinice mijenja se kut upada strujnica zraka čime se smanjuje otpor zraku, a time i uzgon. Zbog toga se značajno smanjuje utrošak energije za povlačenje lebdeće jedinice prema zemlji putem kabla i motora na kolutu na zemaljskom postrojenju. Utrošak energije na vraćanje lebdeće jedinice zauzima samo 25-30% od ukupnog udjela energije koja se dobije fazom proizvodnje. Faza vraćanja u prvobitni položaj završava kada lebdeća jedinica dostigne svoju minimalnu visinu. Tada se cjelokupni ciklus ponavlja [16]. Faza vraćanja u prvobitni položaj prikazana je na Slika 2 [2].



Slika 1 : Faza proizvodnje



Slika 2 : Faza vraćanja u prvobitni položaj

1.3.2. KiteGen

KiteGen je projekt tvrtke KiteGen koji je još uvijek u tijeku ispitivanja prototipa. Zanimljivost ovog prototipa jest što se sastoji samo od platnenog padobranskog krila takozvanog zmaja i dva kabela koja su povezana sa zemaljskim postrojenjem [18]. Zemaljsko postrojenje sastoji se rotacijskog mehanizma, električnih generatora i motora te kontrolne jedinice. Cijeli sistem također sadrži neku vrste pohrane električne energije u slučaju da nema mogućnost direktnog priključka na mrežu. Zmaj može dostići visin i do 1000 metara a sustav radi po sličnom principu kao i prethodni HAWK sistem. Zrak polako uzdiže zmaj dok motori laganim naizmjeničnim povlačenjem kablova tjeraju zmaja da se giba u osmicu čime se smanjuje preopterećenost kablova. Tijekom uzdizanja zmaja i otpuštanjem kablova generira se putem generatora električna energija koja se pohranjuje u spremnik električne energije. kada zmaj dostigne spoju maksimalnu visinu, zmaj se zaklapa, spušta na zemlju i vučom kablova vraća se u prvobitni položaj. Ciklus se zatim ponavlja. Cijeli sustav može biti potpuno autonoman. Velika prednost ovog prototipa je što cijela površina zmaja aktivno sudjeluje u generiranju energije dok kod konvencionalnih vjetroturbina to čini samo oko 30% od cijele vjetroturbine. Zbog toga je cijena instalacije po kWh značajno manja u odnosu na konvencionalne vjetroturbine, ali i sama težina uređaja za istu proizvodnu snagu [19].

1.3.3. MARS

MARS je projekt tvrtke Maggen inc. i trenutno je neaktivan. MARS je zapravo vjetroturbina koja nema svoj toranj niti postolje. Punjena je helijem pa je stoga lakša od zraka i može lebdjeti na visinama i do 300 metara, a pričvršćena je kablovima za zemaljsko postrojenje koje je spojeno na mrežu ili u protivnom sadrži uređaj za pohranu električne energije. Vjetroturbina se okreće oko horizontalne osi dok zrak nastrujava okomito na nju. Helijem možemo kontrolirati visinu MARSa, a stabilnost turbine i njene rotacije donosi Magnussov efekt. Konstrukcija MARSa se sastoji od aluminijske lopatica, cilindričnog balona, stabilizatora vjetroturbine, osovine, kablova i generatora. Neke od prednosti ovog projekta su niska cijena proizvodnje električne energije, tihi rad, veliki raspon brzine vrtnje rotorskih lopatica, manji limiti za lokaciju, mobilnost sustava [20].

1.3.4. Laddermill

Laddermill je koncept nizozemskog fizičara Wubbo Ockelsa, čiji koncept nije još došao do faze prototipa. Laddermill je zamišljen kao dugačak niz ili petlja napravljena od zmajeva. Takav niz ili petlja bi bili pušteni u rad tako da bi snaga zmaja pokrenuta vjetrom okretala generator koji bi proizvodio struju. Takav sistem bi mogao ići i do nekoliko kilometara uvis [21].

1.3.5. BAT

BAT je projekt tvrtke Altaeros energies i trenutno je u tijeku ispitivanja prototipa. BAT se sastoji od četiri komponente: ljuska, turbine, kablovi i zemaljsko postrojenje. Ljuska oblikom podsjeća na mlazni motor aviona, a punjena je helijem i aerodinamički napravljena za stabilan rad i kontrolirani let. Unutar ljuske precizno je smještena konvencionalna turbine sa horizontalnom osi. Ljuska sa turbinom pričvršćena je kablovima za pokretnu zemaljsku stanicu. BAT postiže visine i do 600 metara [3][22].

1.3.6. Makani Wind Power Airbourne Wind Turbine

Makani Wind Power Airbourne Wind Turbine je projekt tvrtke Makani, a trenutno je neaktivan. Makani uređaj je za istu snagu ima 90% manje materijala i proizvodi 50% više energije nego konvencionalna vjetroturbina. Sastoji se od četiri komponente: mali avion, kabel, zemaljska stanica i upravljački kompjutorski sistem. Avion sa dva mala propelera na svojim krilima simulira rad samih krajeva vjetroturbinskih lopatica koji proizvode najviše energije. Avion, spojen sa elastičnim kablom za zemaljsku stanicu, se lansira te potom kruži u velikim krugovima i generira električnu energiju. Cijeli rad nadzire kompjutorski sistem pa zbog toga Makani uređaj može raditi autonomno [1].

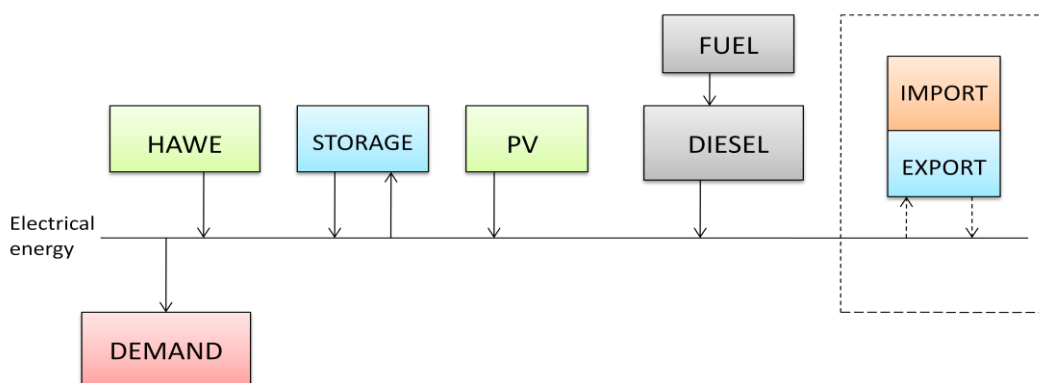
1.3.7. PowerPlane

PowerPlane je projekt tvrtke Ampyx Power i trenutno je u tijeku ispitivanja prototipa. Sustav se sastoji od bezpilotne letjelice koja je računalno programirana, od kabla i od zemaljske stanice. Letjelica vuče kabel svojim kružnim repetitivnim letenjem i time generira električnu energiju. Kada je kabel izvučen do kraja letjelica se spušta na niže visine, kabel povlači letjelicu prema sebi. u odnosu na dobivenu energiju, energija povlačenja aviona je jako mala [23].

Prije nego se krene na samu problematiku zadatka definirat će se inicijalni problem na način da će se opisati sustav i njegove komponente. Zatim će se pojasniti sama metodologiju zadatka i prikazati analiza rezultata te na kraju donijeti zaključak o isplativosti cijelog sustava.

2. DEFINICIJA PROBLEMA


U ovom radu analizirati će se slučaj jednog izoliranog EE sustava koji se sastoji od zadane potražnje za električnom energijom, jedinice za proizvodnju električne energije iz visinskih vjetrova sa sustavom za pohranu energije, dizelskih te fotonaponskih jedinica. Simulacijom u EnergyPLAN-u [24] procijenit ćemo isplativost cijelog sustava za proizvodnju električne energije iz visinskih vjetrova, za 20 godina, temeljem njihovog niveliranog troška proizvodnje električne energije te naknadno izračunate unutrašnje stope povrata. Osim toga, procijenit ćemo koliko se povećava isplativost projekta ukoliko se omogući spoj sustava s glavnom elektroenergetskom mrežom. Jedan od problema će biti odabrati najbolji mogući scenarij koji će biti optimalan za naš EE sustav i koji će zadovoljiti zadanu potražnju za električnom energijom. Blok shema koja prikazuje sve komponente EE sustava te njihov međusobni odnos prikazana je na Slika 3.



Slika 3 : Blok shema EE sustava

2.1. HAWE jedinica


Unutar EE sustava biti će integrirana HAWE jedinica čija krivulja toka će biti unaprijed poznata. Morat će se ispitati njena isplativost unutar zadanog sustava kada ne postoji mogućnost uvoza i izvoza električne energije, a potom kad postoji mogućnost uvoza i izvoza. Krivulja distribucije HAWE jedinice tokom cijele godine prikazana je na Slika 4. Apscisa označava vrijeme u satima, a ordinata opterećenje u MW-ima. Krivulja je izvučena iz EnergyPLAN-a. Kapacitet HAWE jedinica u će također biti zadan i on će iznositi 1000MW.



Slika 4 : Satna krivulja distribucije HAWE jedinice

2.2. Potrošnja električne energije (Demand)

Potražnja za električnom energijom biti će unaprijed poznata i ona će biti referenca za daljnji proračun. Krivulja satne potrošnje električne energije u jednoj godini prikazana je na Slika 5. Apscisa označava vrijeme u satima, a ordinata opterećenje u GW-ima. Krivulja je izvučena iz EnergyPLAN-a..




Slika 5 : Satna krivulja potrošnje električne energije

2.3. Spremnik električne energije (Storage)

U slučaju zadovoljenja potražnje električne energije, višak proizvedene energije u slučaju da nema njenog izvoza ili ako i zadovoljimo izvozne norme morat će se pohraniti u spremnik električne energije. Spremnik električne energije i PV jedinica će biti jedini faktori koji će se moći mijenjati da se zadovolji potražnja za električnom energijom, a da ujedno cijeli sustav bude najviše isplativ. Detaljnijom analizom spremnika električne energije bavi se znanstveni članak [25].

2.4. Fotonaponske jedinice (PV)

Fotonaponske jedinice su također dio referentnog elektroenergetskog sustava i njihova krivulja toka će biti unaprijed poznata. Krivulja distribucija PV jedinice tokom cijele godine prikazana je na Slika 6. Apscisa označava vrijeme u satima, a ordinata opterećenje u MW-ima. Krivulja je izvučena iz EnergyPLAN-a..



Slika 6 : Satna krivulja distribucije PV jedinice

2.5. Diesel jedinica i gorivo (Fuel)

Diesel jedinica biti će potrebna jedino u slučaju kada potražnju ne možemo zadovoljiti iz HAWE i PV jedinica tj. kada ćemo imati vršna opterećenja. Potrošnja goriva bit će jedan od pokazatelja isplativosti sustava.


2.6. Uvoz/Izvoz električne energije (Import/Export)

U prvom dijelu proračuna uvoz i izvoz električne energije neće imati nikakvu ulogu, no u drugom dijelu proračuna morat će se i njih uzeti u obzir. Uvožit će se električna energija ako se potražnja električne energije ne može zadovoljiti iz HAWE, PV i Diesel jedinica. Izvožit će se električna energija u slučaju kada će potražnja za električnom energijom biti zadovoljena, a spremnik električne energije pun.

3. METODOLOGIJA

3.1. Dijagram toka


Dijagram toka koji je prikazan Slika 7 pojašnjava postupak rješavanja zadanog problema. Postupak kreće u EnergyPLAN-u sa zadanom potražnjom za električnom energijom te također zadanim krivuljama satne distribucije HAWE i PV jedinica. Konfigurirajući instaliranu snagu PV-a i veličinu spremnika električne energije pokušavat će se dobiti najoptimalniji slučaj koji će zadovoljavati kriterij najnižih ukupnih troškova. Kada se dobije najoptimalniji slučaj brojnim iteracijama, s tim slučajem se odlazi u Microsoft Excel gdje se računa njegov IRR, LCOE te analizu osjetljivosti kada mijenjamo godišnju investiciju HAWE jedinice. Računat će se 4 slučaja gdje prvi nema uvoza/izvoza, a ostala 3 slučaja imaju različiti maksimalni dopušteni uvoz/izvoz električne energije u MW-ima.



Slika 7 : Dijagram toka

3.2. EnergyPLAN

U sklopu ovog zadatka provest će se računalne simulacije u programu EnergyPLAN. Izračunat će se energetske tokovi i cijena sustava na godišnjoj razini. To je računalni model razvijen na Sveučilištu u Aalborgu, u Danskoj i trenutno je besplatan. Dostupan je na [24]. Njegova glavna funkcija je analiza energetske, okolišne i ekonomske utjecaja različitih energetske strategije. Cilj je razvijanje više različitih rješenja kako bi ona mogla biti međusobno uspoređivana, što se svakako smatra efikasnijim od korištenja samo jednog rješenja. Na taj način, model se koristi u razvoju nacionalnih energetske strategije kroz energetske planiranje. Strategija energetske planiranja bazira se na analizi različitih nacionalnih energetske sustava kroz dva aspekta – tehnički, uključujući tehničke karakteristike sustava i njegove komponente i ekonomski, koji podrazumijeva različite troškove investicije, potrošnje, cijene i ostale tržišne parametre. Model je korišten za analizu na nacionalnoj, regionalnoj i europskoj razini. Njegov ulazno/izlazni model sastoji se od tri sektora: električna energija, toplinska energija i transport, što pokazuje Slika 8.



Slika 8 : Shematski prikaz EnergyPLAN programa

Model je razvijen 1999. godine te od samog početka naglašava analizu različitih regulacijskih strategija s posebnim naglaskom na interakciju između CHP sustava i OIE. Uz to, model se temelji na definiraju i analizi ulaznih i izlaznih parametara. Ulazni parametri su obnovljivi izvori energije, potrošnja energije, kapaciteti instaliranih postrojenja, troškovi i razne regulacijske strategije. Izlazni parametri su energetske bilance, godišnja proizvodnja, potrošnja energije, uvoz i izvoz energije te ukupni troškovi.

Fokus ovog modela je na budućim energetske sustavima i načinu njihovog rada. Model funkcionira deterministički, što znači da za iste vrijednosti ulaznih parametara, uvijek dobivamo iste izlazne parametre. To je bitna razlika u odnosu na stohastičke modele i modele koje koriste Monte Carlo metodu. On također optimizira upravljanje radom zadanog sustava, a ne investicije u taj sustav. Naravno, analizirajući različite sustave i njihove investicije, moguće je doći do zaključaka o isplativosti.

valja napomenuti i kako model radi sa satnim vremenskim korakom, odnosno kako analizira sustav kroz jednu godinu podijeljenu na 8784 vremenskih koraka, što za posljedicu ima mogućnost analize oscilacije OIE na sustav, kao i tjedne i sezonske razlike u zahtjevima za električnom i toplinskom energijom.

3.3. IRR

Nakon što se odabere optimalni scenarij prvo se izračunava IRR. Ova metoda uzima u obzir i veličinu i timing očekivanog cash flow-a u određenom periodu životnog vijeka projekta. IRR za prijedlog investicije jest ona diskontna stopa koja izjednačava sadašnju vrijednost očekivanih troškova sa sadašnjom vrijednosti očekivanih prihoda ili drugim riječima neto sadašnja vrijednost svih novčanih tokova izjednačava se sa nulom ($NPV=0$). Ako je IRR veća od važeće diskontne stope, prijedlog se prihvata; ako ne, prijedlog se odbacuje [26][27].

IRR se računa za jednu godinu i da bi isplativost bila što veća IRR mora biti što veći.

3.4. LCOE

Nakon što se izračuna IRR, kreće se sa izračunavanjem LCOE-a. LCOE je ekonomska procjena prosječnog ukupnog troška gradnje i rada postrojenja za proizvodnju energije za vrijeme njegovog životnog vijeka trajanja čiji je trošak sveden na sadašnju vrijednost. Ta procjena je podijeljena sa ukupnom isporučenom električnom energijom tog postrojenja tijekom njegovog životnog vijeka trajanja. Možemo reći i da je to mjera izvora napajanja koja pokušava spojiti različite načine proizvodnje električne energije na način da se mogu uspoređivati [27][28].

Prilikom računanja troška moramo uzeti u obzir nekoliko troškovnih faktora:

- Investicijski troškovi – niži su za postrojenja na fosilna goriva, a viši za vjetroturbine, fotonaponske jedinice, a najviši za postrojenja na biomasu, energiju valova te plime i oseke i nuklearna postrojenja
- Troškovi goriva - veći su za fosilna goriva i biomasu, manji za nuklearna goriva, dok za obnovljive izvore energije oni su jednaki nuli
- Troškovi rada i održavanja – variraju i različiti su za različite tehnologije, ali za razliku od prva dva faktora puno su manji. Troškovi kao što su troškovi otpada ili troškovi osiguranja se u ovoj računici ne uzimaju u obzir

Da bi procijenili ukupan trošak proizvodnje električne energije moramo ga svesti na sadašnju vrijednost.

Formula [28] po kojoj se računa LCOE glasi:

$$LCOE = \frac{\sum_{t=1}^n \frac{I_t + M_t + F_t}{(1+r)^t}}{\sum_{t=1}^n \frac{E_t}{(1+r)^t}}$$

Brojnik se računa u novčanoj jedinici (€, \$, £, kn...), dok nazivnik u kWh stoga se LCOE računa kao $\frac{\text{novčana jedinica}}{\text{kWh}}$.

Gdje je:

- LCOE – Levelized cost of electricity
- I_t – Investicijski troškovi u godini t
- M_t – Troškovi rada i održavanja u godini t
- F_t – troškovi goriva u godini t
- E_t – Količina proizvedene električne energije u godini t
- r – diskontna stopa
- n – Životni vijek trajanja

Računat će se LCOE za HAWE i PV za svih dvadeset godina odjednom. Kod HAWE-a i PV-a troškova goriva su nepostojeći, ali su investicijski troškovi povišeni u odnosu na konvencionalne tehnologije. Isplativost je tim bolja što je LCOE manji.

3.5. Analiza osjetljivost

Dok se izračuna IRR i LCOE jedino što preostaje je vidjeti kako sustav reagira na promjenu određene varijable i parametre, a to se najlakše može vidjeti sa analizom osjetljivosti. Analiza osjetljivosti predstavlja veoma jednostavnu metodu koja se koristi za lociranje i procjenu mogućih rizika koji utječu na profitabilnost projekata. Bitno je ne samo kvantificirati rizik već i utvrditi čimbenike na čiju je promjenu projekt posebno osjetljiv. Ova analiza ne uzima u obračun vjerojatnost, nego samo raspravlja ima li projekt izgleda za uspjeh ili ne. Pomoću analize osjetljivosti utvrditi će se čimbenici koji utječu na smanjenje isplativosti projekata i njihovim korištenjem izvršit će se odabir investicijskog projekta iz raspoloživog spektra alternativa, koji pokazuje najmanju osjetljivost. Analiza osjetljivosti je proces variranja ulaznih parametara modela unutar dopuštenog područja i promatranje zavisnih promjena u rješenju modela. Ona proučava kako se promjene u outputu modela mogu kvalitativno i kvantitativno dodijeliti različitim izvorima promjena. Ona određuje koliko je odluka osjetljiva na varijaciju numeričkih vrijednosti nesigurnih faktora. Jedan od načina jest pronalaženje graničnih vrijednosti nesigurnih faktora [27][29].

Analiza osjetljivosti se sastoji od postupka opterećivanja projekta različitim negativnim situacijama koje se možda mogu pojaviti tijekom životnog vijeka sustava. Također sustav se podvrgava promjenama svih predvidivih kritičnih parametara. U analizi osjetljivosti

projekta određujemo jednu ili više rizičnih pretpostavki. Za razliku od metode praga rentabilnosti koja pripada statičkom pristupu ocjene neizvjesnosti, analiza osjetljivosti služi se informacijama za vrijeme cijelog vijeka projekta i kao takva analiza osjetljivosti je dinamičan pristup ocjene neizvjesnosti [29].

Analiza osjetljivosti je ustvari varijacija na analizu scenarija i korisna je u određivanju područja gdje je rizik teško identificirati. Također, ideja ove analize je zamrzavanje svih varijabli u modelu diskontnog toka novca osim jednog, a potom vidjeti kako je NPV osjetljiv kada se promijeni ta varijabla. NPV je vrlo osjetljiv na relativno male promjene u projiciranim vrijednostima neke komponente u novčanim tokovima projekta. Ovom analizom se mjere posljedice promjena, ali nažalost ne ukazuje na to koja je vjerojatnost da će do tih promjena doći. Koristeći se analizom osjetljivosti kvantificira se koliko je projekt stabilan ako promijenimo početne ulazne parametre, odnosno koliko je svaki projekt osjetljiv na promjene, a da još uvijek pokazuje pozitivnu NPV odnosno IRR projekta [29].

Primjena analize osjetljivosti je popularna u financijskim aplikacijama, analizi rizika te u bilo kojim područjima gdje se razvijaju modeli. Ujedno se može primijeniti u studiji procjene baziranoj na modelima. Analiza osjetljivosti može pomoći u različitim slučajevima kao što su identifikacije ključnih pretpostavki, pri usporedbi alternativnih struktura modela, otkrivanju važnih kriterija, optimizaciji raspodjele resursa ili pojednostavljivanju modela [29].

Kod određivanje kritičnih parametara projekta gleda se da oni:

- značajno utječu na učinkovitost projekta
- istovremeno su i neizvjesni.

Broj kritičnih parametara je različit kod različitih projekata, ali najčešće se javljaju :

- iznos investicija
- diskontna stopa
- opseg plasmana na prodajnom tržištu;
- prodajna cijena outputa
- nabavna cijena inputa
- stupanj iskorištenosti kapaciteta
- dužina vijeka projekta
- kamatne stope na kredite
- stopa inflacije

- promjene mjera ekonomske politike
- prekoračenje planiranih rokova izvedbe

Prvo će se utvrditi kritični parametri koji su osnova za korištenje ove analize. Kada se utvrde kritični parametri onda će se pojedinačno svaki od tih kritičnih parametara razmjerno povećavati i smanjivati. Na taj način će se izračunati za koliko postotaka se trebaju smanjiti kritični parametri da bi NPV odnosno IRR projekta bila jednaka nuli.

U analizi slučaja našeg referentnog sustava mijenjat će se godišnja investicija HAWE jedinica. To će biti kritičan parametar koji će se povećavati, ali i smanjivati u odnosu na početnu inicijalnu investiciju s kojom se ušlo u proračun IRR-a i LCOE-a. Mijenjanjem kritičnog parametra, mijenjat će se i IRR i LCOE. Na kraju vidjet će se koliko je sustav osjetljiv na promjenu kritičnog parametra te u koje slučaju je sustav najisplativiji.

4. ANALIZA REZULTATA

4.1. Analiza ukupnih troškova zadanih scenarija

U EnergyPLAN krenulo se sa već poznatim krivuljama satne distribucije za PV i HAWE jedinicu te za potrošnju električne energije. Unutar EnergyPLAN-a jedine varijable koje su se mijenjale su:

- instalirana snaga PV jedinica
- kapacitet električnog spremnika

Ono što se prvo moralo naći jest optimalna točka odnosno kada će ukupni troškovi cijelog sustava biti najmanji za te dvije promjenjive varijable. Budući da se o u početku nije moglo pretpostaviti iterativni postupak je bila jedina opcija. Stoga su se unosile različite vrijednosti i jedne i druge varijable te za svaki unos bilježili ukupni troškovi koji su se očitavali iz outputa. Unašanjem vrijednosti tih varijabli te daljnjim očitavanjem uočilo se kako ukupni troškovi padaju do neke vrijednosti, a zatim se opet povisuju. Što znači da postoji minimum ukupnih troškova za određenu kombinaciju instalirane snage PV jedinica i kapaciteta električnog spremnika. U EnergyPLAN-u vrijednosti instalirane snage PV jedinice unosile se se u rubriku 'Supply' pod 'Electricity only' i to za Photo Voltaic Capacity u MW-ima kao što prikazuje Slika 9.

Overview

- [-] Demand
- [+] Supply
 - [-] Heat and Electricity
 - [-] Electricity Only
 - [-] Heat Only
 - [-] Thermal Plant Fuel Distributi
 - [-] Waste
 - [-] Liquid and Gas Fuels
 - [-] CO2
 - [-] Balancing and Storage
 - [-] Electricity
 - [-] Thermal
 - [-] Liquid and Gas Fuel
 - [-] Cost
 - [-] General
 - [-] Investment and Fixed OM
 - [-] Fuel
 - [-] Variable OM
 - [-] External Electricity Market
 - [-] Simulation
 - [-] Output

Central Power Plants

	Capacity MW-e	Efficiency Percent	Correction Factor: Percent	Annual production: TWh/year	Distributions
PP1 (CHP3 Condensing Mode)*	0,00			n/a*	
Condensing PP2	110	0,45		n/a*	
Nuclear	0	0,33	1	0,00	Change const.txt
Geothermal	0	0	1	0,00	Change const.txt
Dammed Hydro Water supply*				0	Change Hour_wind_1.txt
Dammed Hydro Power	0	0,33		0,00 (Estimated)*	

Intermittent Renewable Electricity

Renewable Energy Source	Capacity: MW	Stabilisation share	Distribution profile	Estimated Production TWh/year	Correction factor	Estimated Post Correction production
Wind	1000	0	Change supply_hawe.txt	0,56	0	0,56
Photo Voltaic	20	0	Change supply_PV.txt	0,03	0	0,03
Offshore Wind	0	0	Change hour_wind_2.txt	0,00	0	0,00
River Hydro	0	0	Change const.txt	0,00	0	0,00
Tidal	0	0	Change hour_tidal_power	0,00	0	0,00
Wave Power	0	0	Change Hour_wave_200*	0,00	0	0,00

Slika 9 : Unos snage PV jedinice

Vrijednosti veličine spremnika električne energije unosile su se u rubriku 'Balancing and Storage' pod 'Electricity' i to za Storage Capacity u GWh-ima kao što prikazuje Slika 10.

Overview

- [-] Demand
- [+] Supply
 - [-] Heat and Electricity
 - [-] Electricity Only
 - [-] Heat Only
 - [-] Thermal Plant Fuel Distributi
 - [-] Waste
 - [-] Liquid and Gas Fuels
 - [-] CO2
 - [-] Balancing and Storage
 - [-] Electricity
 - [-] Thermal
 - [-] Liquid and Gas Fuel
 - [-] Cost
 - [-] General
 - [-] Investment and Fixed OM
 - [-] Fuel
 - [-] Variable OM
 - [-] External Electricity Market
 - [-] Simulation
 - [-] Output

Electric grid stabilisation requirements:

Minimum grid stabilisation production share	0	
Stabilisation share of CHP2	0	
Stabilisation share of Waste CHP	0	
Stabilisation share smart charge EV and V2G	0	Share of charge connection
Stabilisation share transmission line	0	Share of max capacity
Minimum CHP in gr. 3:	0	MW
Minimum PP:	0	MW

Electricity Storage

	Capacities	Efficiencies	Fuel Ratio *)	Storage Capacity
Pump/Compressor	1000	0,9		10 GWh
Turbine	1000	0,9	0	

Allow for simultaneous operation of turbine and pump: No


*) Fuel ratio = fuel input / electric output (for CAES technologies or similar)

Slika 10 : Unos veličine električnog spremnika

Na temelju uočenog odredilo se pet referentnih točaka za jednu i pet referentnih točaka za drugu varijablu. S tim točkama se dalje otišlo u analizu ukupnih troškova za zadane scenarije. Gledala su se 4 scenarija na koja se referentni sustav podvrgnuo. To su:

1. Sustav bez dopuštenog uvoza ni izvoza električne energije
2. Sustav sa dopuštenim uvozom i izvozom električne energije od 10MW
3. Sustav sa dopuštenim uvozom i izvozom električne energije od 50MW
4. Sustav sa dopuštenim uvozom i izvozom električne energije od 100MW

Za sva 4 scenarija morale su se naći optimalne točke odnosno točke u kojima su ukupni troškovi minimalni. Vrijednosti dopuštenog uvoza i izvoza električne energije unosile su se u rubriku Cost pod 'External Electricity Market' i to za Maximum import/export capacity u MW-ima kao što prikazuje Slika 11.



Slika 11 : Uvoz dopuštenog uvoza i izvoza električne energije

Nakon što su se odabrale referentne točke za obje varijable u prvom scenariju odradilo se 25 simulacija. U naredna tri scenarija odnosno slučaja mijenjao se dopušteni uvoz i izvoz električne energije i također sa istim referentnim točkama odradilo se 25 simulacija. Na kraju imali smo 100 simulacija, svi rezultati su se zapisali u Excel tablicu i dobili smo 4 najoptimalnije točke s obzirom na ukupne troškove. EnergyPLAN daje uvid i u iznos varijabilnih, fiksnih i investicijskih troškova referentnog sustava.

U prvom scenariju minimalni ukupni godišnji troškovi iznose 9 milijuna eura uz 100 MW instalirane snage PV modula te 100 GWh električnog spremnika. U drugom scenariju minimalni ukupni troškovi ostaju jednaki uz iste instalirane kapacitete uz povećanje dopuštenog izvoza i uvoza električne energije od 10 MW. U trećem scenariju minimalni ukupni troškovi ostaju također jednaki kao i u prvom i drugom scenariju, ali uz povećanu instaliranu snagu PV modula od 750 MW i dopuštenog uvoza i izvoza električne energije na 50 MW, a smanjenog kapaciteta spremnika električne energije na 50 GWh. U četvrtom scenariju minimalni ukupni troškovi padaju na 4 milijuna eura, uz 750 MW instalirane snage PV modula te 50 GWh električnog spremnika, kao i u trećem scenariju, uz povećanje dopuštenog izvoza i izvoza električne energije na 100 MW. Količina instalirane snage HAWE jedinica je konstantan u sva 4 scenarija i ona iznosi 1000 MW. Tablica 1 zorno prikazuje optimalne točke minimalnih ukupnih troškova.


Tablica 1 : Optimalne točke minimalnih ukupnih troškova

	Minimalni ukupni troškovi, Mil. Eur	Instalirana snaga PV modula, MW	Kapacitet spremnika električne energije, GWh	Uvoz/izvoz, MW	Instalirana snaga HAWE jedinica, MW
1. scenarij	9	100	100	0	1000
2.scenarij	9	100	100	10	1000
3.scenarij	9	750	50	50	1000
4.scenarij	4	750	50	100	1000


Grafikon 1, Grafikon 2, Grafikon 3 i Grafikon 4 prikazuju ukupni godišnji trošak u ovisnosti o instaliranoj snazi PV-a i spremniku električne energije od 1. do 4. scenarija. Kod ovih grafikona uzete su u obzir sve točke ukupnih troškova za svih 25 simulacija po scenariju.

Sva 4 grafikona imaju neki oblik kubne parabole. Grafikon 1 koji predstavlja 1. scenarij i Grafikon 2 koji predstavlja 2. scenarij se ne razlikuju previše iako kod 2. scenarija imamo dopušteni uvoz i izvoz od 10MW. Grafikon 3 koji predstavlja 3. scenarij u odnosu na ostala dva grafikona razlikuje se u tome što ima veći rast na rubovima grafikona tj. ukupni troškovi brže rastu kako se odmiču od točke minimuma. Također, Grafikon 3 ima 2 minimuma: jedan koji je naveden u **Pogreška! Izvor reference nije pronađen.**, a drugi je sa instaliranom snagom PV modula od 750MW i


50 GWh električne energije. Grafikon 4 koji predstavlja 4. scenarij u odnosu na Grafikon 3 se razlikuje po tome što ukupni troškovi na rubovima grafikona još brže rastu kako se odmiču od točke minimuma. Sam minimum je niži kod Grafikon 4 u odnosu na ostale grafikone.




Grafikon 1 : Ukupni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 1. scenarija



Grafikon 2 : Ukupni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 2. scenarija



Grafikon 3 : Ukupni godišnjai trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 3. scenarija



Grafikon 4 : Ukupni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 4. scenarija


Što se tiče fiksnih godišnjih troškova u optimalnoj točki, oni ostaju konstantni kroz sva 4 slučaja i iznose 2 milijuna eura. Fiksni troškovi nisu vezani uz količinu proizvedene energije nego uz instalirani kapacitet tj. to su troškovi rada i održavanja postrojenja. Količina instalirane snage HAWE jedinica je konstantan u sva 4 scenarija i ona iznosi 1000 MW. Tablica 2 prikazuje optimalne točke fiksnih troškova.

Tablica 2 : Optimalne točke fiksnih troškova


	Fiksni troškovi, Mil. Eur	Instalirana snaga PV modula, MW	Kapacitet spremnika električne energije, GWh	Uvoz/izvoz, MW	Instalirana snaga HAWE jedinica, MW
1. scenarij	2	100	100	0	1000
2.scenarij	2	100	100	10	1000
3.scenarij	2	750	50	50	1000
4.scenarij	2	750	50	100	1000

Grafikon 4 prikazuju fiksne godišnje troškove u ovisnosti o instaliranoj snazi PV-a i spremniku električne energije od 1. do 4. scenarija. Kod ovih grafikona uzete su u obzir sve točke fiksnih troškova za svih 25 simulacija po scenariju.


S porastom instaliranih kapaciteta u svim grafikonima odnosno scenarijima proporcionalno rastu i fiksni troškovi. Više-manje grafikonu su slični, jedino se Grafikon 7 koji predstavlja 3. scenarij i Grafikon 8 koji predstavlja 4 scenarij donekle razlikuju od Grafikon 5 i Grafikon 6 po tome što pri nižim instaliranim kapacitetima imaju više vrijednosti fiksnih troškova.




Grafikon 5 : Fiksni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 1. scenarija



Grafikon 6 : Fiksni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 2. scenarija



Grafikon 7 : Fiksni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 3. scenarija



Grafikon 8 : Fiksni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 4. scenarija


Kada promatramo godišnje varijabilne troškove u prvom scenariju varijabilni troškovi iznose 0 milijuna eura uz 100 MW instalirane snage PV modula te 100 GWh električnog spremnika. U drugom scenariju varijabilni troškovi ostaju jednaki uz iste instalirane kapacitete uz povećanje dopuštenog izvoza i uvoza električne energije od 10 MW. U ovom scenariju pojavili su se točke u kojima su varijabilni troškovi negativni, ali uzela se točka u kojoj su varijabilni troškovi nula jer u njoj su ukupni troškovi minimalni. U trećem scenariju povećanjem instalirane snage PV modula na 750 MW i dopuštenog uvoza i izvoza električne energije na 50 MW te smanjenjem kapaciteta spremnika električne energije na 50 GWh varijabilni troškovi padaju na -6 milijuna eura. To znači da su se u godini dana ovim scenarijem uspjeli pokriti svi varijabilni troškovi i zaraditi 6 milijuna eura proizvodnjom električne energije i njenim izvozom. U četvrtom scenariju varijabilni troškovi dodatno padaju na -11 milijuna eura, uz 750 MW instalirane snage PV modula te 50 GWh električnog spremnika, kao i u trećem scenariju, uz povećanje dopuštenog izvoza i izvoza električne energije na 100 MW. Količina instalirane snage HAWE jedinica je konstantan u sva 4 scenarija i ona iznosi 1000 MW. Tablica 3 prikazuje optimalne točke varijabilnih troškova.

Tablica 3 : Optimalne točke varijabilnih troškova


	Varijabilni troškovi, Mil. Eur	Instalirana snaga PV modula, MW	Kapacitet spremnika električne energije, GWh	Uvoz/izvoz, MW	Instalirana snaga HAWE jedinica, MW
1. scenarij	0	100	100	0	1000
2.scenarij	0	100	100	10	1000
3.scenarij	-6	750	50	50	1000
4.scenarij	-11	750	50	100	1000

Grafikon 9, Grafikon 10, Grafikon 11 i Grafikon 12 prikazuju varijabilni godišnji trošak u ovisnosti o instaliranoj snazi PV-a i spremniku električne energije od 1. do 4. scenarija. Kod ovih grafikona uzete su u obzir sve točke varijabilnih godišnjih troškova za svih 25 simulacija po scenariju.


Za razliku od fiksnih troškova, varijabilni troškovi na svim grafikonima padaju sa povećanjem instaliranih kapaciteta. S povećanjem dopuštenog uvoza i izvoza primjećuje se na Grafikon 11, koji predstavlja 3. scenarij, i Grafikon 12, koji predstavlja 4. slučaj, da varijabilni troškovi prelaze u negativno područje nakon određenog instaliranog kapaciteta. Također povećanjem uvoza i izvoza električne energije povećavaju se varijabilni troškovi pri nižim instaliranim kapacitetima.




Grafikon 9 : Varijabilni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 1. scenarija



Grafikon 10 : Varijabilni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 2. scenarija



Grafikon 11 : Varijabilni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 3. scenarija



Grafikon 12 : Varijabilni godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 4. scenarija


U sklopu fiksnih troškova posebnu ulogu imaju i investicijski troškovi. U prvom scenariju investicijski troškovi iznose 7 milijuna eura uz 100 MW instalirane snage PV modula te 100 GWh električnog spremnika. U drugom scenariju investicijski troškovi ostaju jednaki uz iste instalirane kapacitete uz povećanje dopuštenog izvoza i uvoza električne energije od 10 MW. U trećem scenariju povećanjem instalirane snage PV modula na 750 MW i dopuštenog uvoza i izvoza električne energije na 50 MW te smanjenjem kapaciteta spremnika električne energije na 50 GWh investicijski troškovi rastu na 12 milijuna eura. U četvrtom scenariju investicijski troškovi dodatno rastu na 13 milijuna eura, uz 750 MW instalirane snage PV modula te 50 GWh električnog spremnika, kao i u trećem scenariju, uz povećanje dopuštenog izvoza i izvoza električne energije na 100 MW. Količina instalirane snage HAWC jedinica je konstantan u sva 4 scenarija i ona iznosi 1000 MW. Tablica 4 prikazuje optimalne točke investicijskih troškova.

Tablica 4 : Optimalne točke investicijskih troškova


	Investicijski troškovi, Mil. Eur	Instalirana snaga PV modula, MW	Kapacitet spremnika električne energije, GWh	Uvoz/izvoz, MW	Instalirana snaga HAWE jedinica, MW
1. scenarij	7	100	100	0	1000
2. scenarij	7	100	100	10	1000
3. scenarij	12	750	50	50	1000
4. scenarij	13	750	50	100	1000

Grafikon 13, Grafikon 14, Grafikon 15 i Grafikon 16 prikazuju investicijski godišnji trošak u ovisnosti o instaliranoj snazi PV-a i spremniku električne energije od 1. do 4. scenarija. Kod ovih grafikona uzete su u obzir sve točke investicijskih godišnjih troškova za svih 25 simulacija po scenariju.


Grafikoni godišnjih investicijskih troškova također bilježe rast sa povećanjem instaliranih kapaciteta sustava, budući da su varijabilni troškovi vezani uz fiksne troškove. Međutim taj rast je konstantniji i glađi od fiksnih troškova. Grafikoni se ne razlikuju previše jedan od drugog i u istim točkama imaju više-manje jednake vrijednosti investicijskih troškova.




Grafikon 13 : Investicijski godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 1. scenarija



Grafikon 14 : Investicijski godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 2. scenarija



Grafikon 15 : Investicijski godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 3. scenarija



Grafikon 16 : Investicijski godišnji trošak u ovisnosti o instaliranom PV-u i spremniku el. energije 4. scenarija

4.2. Analiza unutarnje stope povrata


Prvi korak gdje su se našle optimalne točke i izračunali minimalni ukupni godišnji troškovi u EnergyPLAN-u za sva četiri scenarija je riješen. Drugi korak je izračunati unutarnju stopu povrata, skraćeno IRR. Prvo se popiše za svaki scenarij optimalni kapaciteti PV-a, HAWE-a i spremnika električne, dopušteni uvoz i izvoz električne energije te izračunati minimalni ukupni troškovi u optimalnoj točki, kao što prikazuje Tablica 5 : Analiza IRR-a za sve scenarije. Zatim se izračuna godišnji prihod od distribucije električne energije potrošačima na način da se pomnoži ukupna godišnja potražnja za električnom energijom od 0,56 TWh po godini sa cijenom električne energije od 30 eura po MWh. Ukupni godišnji prihod od distribucije električne energije potrošačima iznosi 16,8 milijuna eura, prikazano u Tablica 5 : Analiza IRR-a za sve scenarije. On sa sva četiri scenarija ostaje isti. No, porastom dopuštenog uvoza i izvoza raste i godišnji prihod od izvoza električne energije. Tako u 1. scenariju on iznosi 0 milijuna eura, u 2. scenariju 0,3 milijuna eura, u 3. scenariju 6 milijuna eura, a u 4. scenariju najvećih 11 milijuna eura.

Nakon što se sve navedeno u Tablica 5 unijelo u Excel, zajedno sa svim godišnjim investicijskim i fiksnim troškovima EE sustava izračunao se IRR za sve scenarije posebno. Rezultat je takav da IRR za 1. scenarij iznosi 8,51%, za 2. scenarij 8,78%, za 3. scenarij 9,27%, a za 4. scenarij najvećih 14,32%.

Tablica 5 : Analiza IRR-a za sve scenarije


	1. scenarij	2. scenarij	3. scenarij	4. scenarij
instalirana snaga PV modula, MW	100	100	750	750
Kapacitet spremnika električne energije, GWh	100	100	750	50
Instalirana snaga HAWE jedinica, MW	1000	1000	1000	1000
Uvoz/izvoz, MW	0	10	50	100
Godišnji prihod od distribucije el. Energije potrošačima, Mil. Eura	16,8	16,8	16,8	16,8
Godišnji prihod od izvoza el. Energije, Mil. Eura	0	0,3	6	11
Ukupni godišnji trošak, Mil. Eur	9	9	9	4
IRR	8,51%	8,78%	9,27%	14,32%

Kretanje IRR-a za svaki scenarij zorno prikazuje Grafikon 17. Vrlo lijepo se može vidjeti kako IRR lagano raste od 1. do 3. scenarija i onda ima nagli skok u 4. scenariju.



Grafikon 17 : Kretanje IRR-a po scenarijima

Grafikon 18 prikazuje kako se međusobno kreću godišnji prihodi od električne energije. Dok je godišnji prihod od distribucije električne energije potrošačima konstantan, godišnji prihod od izvoza električne energije raste kroz scenarije. Od 1. scenarija do 2. scenarija raste vrlo sporo, no od 2. scenarija do 4. scenarija raste intenzivno.



Grafikon 18 : Kretanje godišnjih prihoda od el. energije

4.3. Analiza niveliranog troška električne energije

Nakon izračunatog IRR-a, sljedeći korak je izračunati nivelirani trošak električne energije, skraćeno LCOE. Njega se izračunalo na način da su se prvo popisali svi podaci potrebni za njegov izračun. To su za svaki scenarij optimalni kapaciteti PV-a, HAWE-a i spremnika električne te dopušteni uvoz i izvoz električne energije kao što prikazuje Tablica 6. Također, bila nam je potrebna proizvedena godišnja električna energija iz HAWE jedinica i PV modula u GWh-ima. U 1. scenariju za HAWE jedinice ona iznosi 490 GWh, a za PV module 150 GWh. Za 2. scenarij 510 GWh iz HAWE jedinica, 150 GWh iz PV modula. U 3. scenariju ona iznosi 170 GWh za HAWE jedinice i 650 GWh za PV module. I na kraju, u 4. scenariju 220 GWh iz HAWE jedinica i 760 GWh iz PV modula. Zorni prikaz usporedbe proizvedene godišnje električne energije od HAWE i PV jedinica daje Grafikon 20. Jedino što se još trebalo upisati u tablicu su investicijski i fiksni troškovi za PV module i HAWE jedinice u eurima. I investicijski i fiksni troškovi uglavnom se kreću oko milijun eura, jedino u 3. i 4. scenariju godišnji investicijski trošak iznosi 8 milijuna eura, dok fiksnih troškova PV modula u 1. i drugom scenariju ne postoje. Troškovi goriva za HAWE i PV logično ne postoje


Nakon svih popisanih podataka, LCOE za HAWE i PV vrlo se lako izračuna. Postupak je opisan pod točkom 3.4. U 1. scenariju LCOE za HAWE iznosi 0,0041 Eura po kWh, dok za PV 0,0067 Eura po kWh. LCOE za HAWE 2. scenarija iznosi 0,0039 Eura po kWh, dok za PV ostaje jednak, 0,0067 Eura po kWh. U 3. scenariju on za HAWE iznosi 0,0118, a za PV 0,0138 Eura po kWh. I na kraju, u 4. scenariju LCOE HAWE iznosi 0,0091, a LCOE PV 0,0118 Eura po kWh.

Razlog zbog kojeg se nije računao LCOE za Diesel jedinicu je taj što Diesel jedinica ni u jednom scenariju nije sudjelovala u godišnjoj proizvodnji električne energije. To pokazuje podatak iz Energy plana gdje je u sva 4 scenarija pokazivao da je 'RES Share of PES' jednak 100% što znači da je udio obnovljivih izvora energije u primarnoj energiji stopostotan.

Tablica 6 : Analiza LCOE-a


	1. scenarij	2. scenarij	3. scenarij	4. scenarij
instalirana snaga PV modula, MW	100	100	750	750
Kapacitet spremnika električne energije, GWh	100	100	750	50
Instalirana snaga HAWE jedinica, MW	1000	1000	1000	1000
Uvoz/izvoz, MW	0	10	50	100
Proizvedena godišnja el. Energija iz HAWE jedinica, GWh	490	510	170	220
Proizvedena godišnja el. Energija iz PV modula, GWh	150	150	650	760
Investicijski godišnji trošak HAWE jedinica, Eur	1000000	1000000	1000000	1000000
Investicijski godišnji trošak PV modula, Eur	1000000	1000000	8000000	8000000
Fiksni godišnji trošak HAWE jedinica, Eur	1000000	1000000	1000000	1000000
Fiksni godišnji trošak PV modula, Eur	0	0	1000000	1000000
LCOE (HAWE), Eur/kWh	0,0041	0,0039	0,0118	0,0091
LCOE (PV), Eur/kWh	0,0067	0,0067	0,0138	0,0118

Na Grafikon 19 prikazana je usporedno kretanje LCOE HAWE i LCOE PV kroz scenarije. Oba LCOE-a imaju slično kretanje kroz scenarije. Oba LCOE naglo rastu u trećem scenariju, dok u 4. scenariju padaju. No, postoje i razlike. LCOE za PV u svim scenarijima veći od LCOE za HAWE. između 1. i 2. scenarija LCOE za PV ostaje konstantan, dok LCOE za HAWE neznatno pada. Između 2. i 3. scenarija LCOE za HAWE sporije raste od LCOE za PV. I na zadnjoj dionici, između 3. i 4. scenarija, LCOE za PV brže pada od LCOE za HAWE.



Grafikon 19 : Usporedba LCOE (HAWE) i LCOE (PV)

Kao što se prije spomenulo Grafikon 20 prikazuje odnos između godišnje proizvedene električne energije što iz HAWE jedinica što iz PV modula. Graf je zanimljiv, iz razloga što se na njemu može vidjeti kako u 2. scenariju i jedna i druga proizvedena električna energija neznatno rastu da bi u 3. scenariju međusobno promijenile gibanje. Povećavanjem kapaciteta PV modula u 3. scenariju vidi se na grafu da je proizvedena godišnja električna energija iz PV modula porasla, dok s druge strane godišnja električna energija iz HAWE jedinica je naglo pala. U 4. scenariju, rast godišnje proizvodnje električne energije PV-a ostaje konstantan dok godišnja proizvodnja električne energije iz HAWE jedinica bilježi ponovni rast.



Grafikon 20 : Usporedba proizvedene godišnje električne energije od HAWE i PV jedinica


Zanimljiva je i Tablica 7 koja pokazuje udjele godišnje proizvedene energije u ukupno godišnje proizvedenoj električnoj energiji. Ukupna proizvedena godišnja električna energija u 1. scenariju je 0,64 TWh, u 2. scenariju ona iznosi 0,66 TWh, u 3. scenariju ona naglo raste na 0,82 TWh, dok u 4. scenariju ona iznosi 0,98 TWh.

Što se tiče udjela u 1. i 2. scenariju udio PV modula u ukupnoj proizvedenoj godišnjoj električnoj energiji iznosi 0,23%, dok udio HAWE jedinica iznosi 77%. U 3. scenariju udio PV modula iznosi 79%, dok HAWE jedinica 21%, dok u zadnjem 4. scenariju udio PV modula je 78%, a HAWE jedinica 22%.

Tablica 7 : Analiza udjela godišnje proizvedene električne energije u ukupno proizvedenoj

	1. scenarij	2.scenarij	3.scenarij	4.scenarij
Proizvedena godišnja el. Energija iz HAWE jedinica, TWh	0,49	0,51	0,17	0,22
Proizvedena godišnja el. Energija iz PV modula, TWh	0,15	0,15	0,65	0,76
Ukupna proizvedena godišnja el. energija, TWh	0,64	0,66	0,82	0,98
Udio PV modula u ukupnoj proizvedenoj godišnjoj el. En.	23%	23%	79%	78%
Udio HAWE modula u ukupnoj proizvedenoj godišnjoj el. En.	77%	77%	21%	22%

Maloprije nabrojano i napisano u Tablica 7 zorno prikazuje Grafikon 21. Vrlo jasno se vidi da u trećem scenariju udio PV modula u ukupnoj proizvedenoj godišnjoj električnoj energiji i udio HAWE jedinica mijenjaju pozicije vodećeg proizvođača električne energije.

**Grafikon 21 : Analiza udjela proizvodnje el. energije PV i HAWE jedinica u odnosu na ukupnu proizvodnju**


4.4. Analiza osjetljivosti

Posljednji korak u ovom radu biti će analiza osjetljivosti gdje će se ispitivati osjetljivost referentnog EE sustava na promjenu godišnjeg investicijskog troška HAWE jedinice. Postupak kreće jednostavnim mijenjanjem maloprije spomenutog investicijskog troška koji iznosi milijun eura godišnje od -20% do +20% sa korakom od 10%. Sa svakom promjenom investicijskog troška za određeni postotak ulazi se u prije izračunati proračun IRR-a. Navedene promjene su se napravile za sve scenarije i potom se novo dobiveni IRR uspoređivao sa starim IRR-om. Svi novi IRR-ovi zajedno sa starim zapisali su se u Tablica 8.

Tablica 8 : Popis IRR-a uslijed analize osjetljivosti za sve scenarija

IRR	-20%	-10%	0%	10%	20%
1. scenarij	9,0%	8,7%	8,5%	8,3%	8,1%
2. scenarij	9,2%	9,0%	8,8%	8,6%	8,4%
3. scenarij	9,5%	9,4%	9,3%	9,2%	9,0%
4. scenarij	14,6%	14,5%	14,3%	14,2%	14,0%

Grafikon 22 prikazuje ono što Tablica 8 ne može a to je kako se kreću IRR-ovi svakog pojedinog scenarija tokom analize osjetljivosti. Također, mogu se vidjeti i njihovi međusobni odnosi. Uočava se kako svi IRR-ovi u svim scenarijima padaju kako se povećava investicijski trošak HAWE jedinice. Također može se vidjeti kako IRR u 4. scenariju pozitivno iskače po iznosu od ostalih i to za velikih 5% .



Grafikon 22 : Usporedba kretanja IRR-a analizom osjetljivosti za sve scenarije


U Tablica 9 unešene su sve promjene novog IRR-a proveden analizom osjetljivosti u odnosu na stari IRR. Promjene idu u pozitivnom smjeru dok je investicijski trošak HAWE jedinica manji od inicijalnog, a u negativnom smjeru dok je investicijski trošak veći od inicijalnog.

Tablica 9 : Popis promjena IRR-a uslijed analize osjetljivosti za sve scenarije

Promjena	-20%	-10%	0%	10%	20%
1. scenarij	0,4%	0,2%	0,0%	-0,2%	-0,4%
2. scenarij	0,4%	0,2%	0,0%	-0,2%	-0,4%
3. scenarij	0,2%	0,1%	0,0%	-0,1%	-0,2%
4. scenarij	0,3%	0,1%	0,0%	-0,2%	-0,3%

Svi podaci koji su u Tablica 9 slikovito su prikazani na Grafikon 23 koji pokazuje kako se kreću promjene IRR-a svakog pojedinog scenarija tokom analize osjetljivosti. Također, mogu se vidjeti i njihovi međusobni odnosi. Uočava se kako su promjene usmjerene od pozitivnog dijela osi ordinata (koja prikazuje postotak promjene IRR-a), krenuvši jeftinijim investicijskim troškom HAWE jedinica, prema negativnom dijelu osi ordinata, završivši

skupljim investicijskim troškom istog. Zanimljivo je također vidjeti kako u 1. i 2. scenariju prelazak promjene iz pozitivnog dijela ordinatne osi prema negativnom je puno brži od 3. i 4. scenarija. U 4. scenariju imamo najsporiji pad postotka promjene IRR-a.



Grafikon 23 : Usporedba kretanja promjena IRR-a analizom osjetljivosti za sve scenarije

5. ZAKLJUČAK

U ovom radu predstavljena je relativno nova tehnologija, tehnologija koja prikuplja energiju visinskih vjetrova te koja je većinom još uvijek u fazi ispitivanja prototipa. Rad se sastojao od elektroenergetskog sustava koji je sadržavao spomenuti HAWE sistem prikupljanja energije zajedno sa fotonaponskim modulima, spremnikom električne energije, Diesel jedinicom i mogućnošću spajanja na mrežu. Elektroenergetski sustav smo podvrgli simulacijama s ciljem da se vidi je li on isplativ te može li se u budućnosti implementirati u postojeće sustave za prikupljanje, pohranu i distribuciju električne energije. Ovim radom došlo se do nekih zanimljivih zaključaka. Ukoliko nemamo mogućnost izvoza ili uvoza električne energije ili je maksimalni kapacitet minimalan, kao što smo imali u prvom i drugom scenariju, instalirana snaga PV modula je manja, a spremnik električne energije veći nego kada je maksimalni kapacitet uvoza i izvoza električne energije veći, kao u trećem i četvrtom scenariju. Također zanimljivo je da su i ukupni troškovi u prvom, drugom pa i trećem scenariju više nego duplo veći od 4. scenarija. Razlog tomu je još uvijek skupa tehnologija proizvodnje električne pohrane sa teškom mogućnošću napretka. No, još jedan razlog je taj što povećanjem izvoza električne energije ne samo da se smanjuju varijabilni troškovi, nego varijabilni troškovi u EnergyPLAN-u odlaze u negativne vrijednosti. To znači da se višestruko zarađuje od prodaje električne energije. Upravo zbog povećanja kapaciteta uvoza i izvoza električne energije pojavljuje se nagli rast IRR-a u četvrtom scenariju, ali i smanjenje LCOE-a za PV module i HAWE jedinice. Dokaz kako je izvoz bitan faktor je taj što u trećem scenariju, koji ima manji kapacitet izvoza električne energije od četvrtog, pojavljuje se naglo povećanje LCOE za PV i HAWE na Grafikon 21. LCOE PV se povećao prvenstveno zbog povećanja kapaciteta PV modula. No, LCOE HAWE se povećao iz razloga što mu je morala pasti proizvodnja električne energije zbog toga što, kada je spremnik električne energije pun, nije postojalo dovoljno kapaciteta izvoza električne energije. Ovaj rad je pokazao kako je Diesel jedinica u ovom elektroenergetskom sustavu nepotrebna jer ne sudjeluje u ukupnoj proizvodnji električne energije iz razloga što se sve uspije pokriti iz obnovljivih izvora energije. Također, spremnik električne energije igra veliku ulogu u tome jer pri vršnom opterećenju, kada nema sunca ili vjetra, električna energija dolazi iz električne pohrane. Loša praksa današnjice je da kada se takvo što dogodi, se uključuje Diesel jedinice. No, praksa budućnosti možda će biti drugačija jer ovaj rad pokazuje kako se višestruko isplati uložiti u ovakav sustav ukoliko se kapaciteti uvoza i izvoza povećaju te ukoliko postoji mogućnost pohrane električne energije.

LITERATURA I REFERENCE

- [1] <http://www.google.com/makani/solution/>
- [2] Perković Luka. Energija visokih vjetrova. BUS predavanje SUPEUS udruge 14.03.2015.; slajd 2
- [3] <http://www.altaerosenergies.com/bat.html>
- [4] Castellani F., Garinei A. On the way to harness high-altitude wind power: Defining the operational asset for an airship wind generator. Applied Energy 2013.; Volume 112, 592-600
- [5] http://hr.wikipedia.org/wiki/Visinske_vjetroelektrane
- [6] Adhikari J., Panda S.K., Overview of high altitude wind energy harvesting system. Conference Paper on PESA 2013 Hong Kong 2013.; Article number 6828249
- [7] Bolonkin A. Utilization of wind energy at high altitude. Conference Paper on 2nd International Energy Conversion Engineering Conference 2004.; Volume 3, 1487-1507
- [8] Canale M., Fagiano L., Milanese M. High altitude wind energy generation using controlled power kites. IEEE Transactions on Control System Technology 2010.; Volume 18, Article number 5152910, 279-293
- [9] Zhao Z., Yang J., Yue H., Li S. Modeling and nonlinear model predictive control of kite system for high altitude wind energy generation. CCC 2014.; Article number 6896155, 6998-7003
- [10] http://en.wikipedia.org/wiki/High-altitude_wind_power
- [11] http://e360.yale.edu/feature/high_altitude_wind_energy_huge_potential_and_hurdles/2576/
- [12] Y. Ji, J. He. Analysis on lightning triggering possibility along transmission tethers of high altitude wind energy exploitation system. Electric Power System Research 2013.; Volume 94 ; 16-23
- [13] Y. Ji, J. He. Lightning triggering possibility by transmission tethers of high altitude wind energy exploitation system. APL2011; Article number 6110236; 800-803
- [14] Luetsch G. High altitude wind power plants: Dealing with the risks. Conference paper of NTS Energie- und Transportsysteme GmbH Berlin 2011.; 10719

- [15] Cherubini A., Papini A., Vertechy R., Fontana M. Airbourne Wind Energy Systms: A review oft he technologies. Renewable and Sustainable Energy Reviws 2015.; Article number 4656, 1461-1476
- [16] <http://www.omnidea.net/hawe/concept.html>
- [17] Perković Luka, Silva Pedro, Duić Neven, Ban Marko, Kranjčević Nenad. Harvesting high altitude wind energy for power production: The concept based on Magnus' effect. Applied Energy 2013; 151-160
- [18] <http://www.kitenergy.net/technology-2/key-points/>
- [19] <http://www.kitegen.com/en/>
- [20] <http://science.howstuffworks.com/environmental/green-science/mars-turbine.htm>
- [21] <http://en.wikipedia.org/wiki/Laddermill>
- [22] <http://phys.org/news/2015-02-turbines-electricity.html>
- [23] <https://www.ampyxpowers.com/>
- [24] <http://www.energyplan.eu/>
- [25] Pavković D., Hoić M., Deur J., Petrić J. Energy storage systems sizing study for a high-altitude wind energy application. Energy 2014.; Volume 76, 91-103
- [26] <http://www.investopedia.com/terms/i/irr.asp>
- [27] http://powerlab.fsb.hr/enerpedia/index.php?title=Glavna_stranica
- [28] http://en.wikipedia.org/wiki/Cost_of_electricity_by_source#Estimates
- [29] Puška Adis. Analiza osjetljivosti u funkciji investicijskog troška. Praktični menadžment 2011.; Vol. II, 80-86